

PR #35397 完整报告

sgl-project/sglang

Support custom draft worker classes in DSpark

合并时间: 2026-08-20 08:48

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/35397>

执行摘要

- 一句话: DSpark 支持自定义 draft worker 类, 默认行为不变。
- 推荐动作: 值得快速浏览, 作为了解 DSpark 扩展机制的参考。关注点: draft_worker_cls 的类型提示和默认值设计, 以及未来若新增测试时需覆盖默认路径回归。

功能与动机

Out-of-tree DSpark 集成可能需要专门的 `TpModelWorker`, 同时希望复用共享的 draft worker 初始化路径。PR body 明确说明动机: *Out-of-tree DSpark integrations may need a specialized TpModelWorker while retaining the shared draft-worker initialization path.*

实现拆解

实现拆解:

1. 在 `python/sglang/srt/speculative/draft_worker_common.py` 的 `build_draft_tp_worker` 函数签名中新增 keyword-only 参数 `draft_worker_cls: type[TpModelWorker] = TpModelWorker`, 默认值保持原有行为; 函数内将 `TpModelWorker` 的实例化替换为 `draft_worker_cls(...)`, 其余初始化逻辑 (如 `draft_model_build_scope`、`vocab_size` 借用、`DraftWorkerBundle` 构造) 完全不变。
2. 在 `python/sglang/srt/speculative/dspark_components/dspark_worker_v2.py` 的 `DSparkWorkerV2.__init__` 中同样新增 `draft_worker_cls` 参数并透传给 `build_draft_tp_worker`, 使得 DSpark 的 draft worker 可由外部自定义。
3. 未修改任何测试、配置或文档, 因为默认路径未变化, 属于纯扩展点添加。

关键文件:

- `python/sglang/srt/speculative/draft_worker_common.py` (模块 草稿工人; 类别 source; 类型 core-logic; 符号 `build_draft_tp_worker`): 核心函数 `build_draft_tp_worker` 新增 `draft_worker_cls` 参数并调整实例化逻辑, 是本次变更的主入口。
- `python/sglang/srt/speculative/dspark_components/dspark_worker_v2.py` (模块 草稿工人; 类别 source; 类型 core-logic; 符号 `DSparkWorkerV2.init`): `DSparkWorkerV2.__init__` 透传 `draft_worker_cls` 给 `build_draft_tp_worker`, 是 DSpark 侧的接入点。

关键符号: `build_draft_tp_worker`, `DSparkWorkerV2.init`

关键源码片段

python/sglang/srt/speculative/draft_worker_common.py

核心函数 `build_draft_tp_worker` 新增 `draft_worker_cls` 参数并调整实例化逻辑，是本次变更的主入口。

```
# python/sglang/srt/speculative/draft_worker_common.py
# 新增 keyword-only 参数 draft_worker_cls, 默认 TpModelWorker, 保持向后兼容
def build_draft_tp_worker(
    *,
    server_args: ServerArgs,
    gpu_id: int,
    ps: ParallelState,
    nccl_port: int,
    target_model_config: ModelConfig,
    algo_label: str,
    attention_backend_override: Optional[str] = None,
    draft_worker_cls: type[TpModelWorker] = TpModelWorker,
) -> DraftWorkerBundle:
    # ... 前面的 draft_backend 解析逻辑不变 ...

    with draft_model_build_scope():
        # 使用传入的类来实例化 draft worker, 默认还是 TpModelWorker
        draft_worker = draft_worker_cls(
            server_args=server_args,
            gpu_id=gpu_id,
            ps=ps,
            nccl_port=nccl_port,
            is_draft_worker=True,
            context_length=target_model_config.context_len,
            draft_attention_backend=draft_backend,
        )

        draft_model_runner = draft_worker.model_runner
        draft_worker.draft_runner = draft_model_runner
        # ... 后续 vocab_size 借用和 bundle 构造不变 ...
    return DraftWorkerBundle(
        draft_worker=draft_worker,
        draft_model_runner=draft_model_runner,
        draft_model=draft_model_runner.model,
        resolved_attention_backend=draft_backend,
    )
```

python/sglang/srt/speculative/dspark_components/dspark_worker_v2.py

`DSparkWorkerV2.__init__` 透传 `draft_worker_cls` 给 `build_draft_tp_worker`, 是 DSpark 侧的接入点。

```
# python/sglang/srt/speculative/dspark_components/dspark_worker_v2.py
class DSparkWorkerV2(BaseSpecWorker):
```

```

def __init__(
    self,
    server_args: ServerArgs,
    gpu_id: int,
    ps: ParallelState,
    nccl_port: int,
    target_worker: TpModelWorker,
    draft_worker_cls: type[TpModelWorker] = TpModelWorker, # 新增参数
):
    super().__init__()
    # ... 原有初始化逻辑不变 ...

    with self._draft_context():
        bundle = build_draft_tp_worker(
            server_args=server_args,
            gpu_id=gpu_id,
            ps=replace(ps, pp_rank=0),
            nccl_port=nccl_port,
            target_model_config=target_worker.model_runner.model_config,
            algo_label="DSPARK",
            attention_backend_override=(
                DSV4_DRAFT_ATTENTION_BACKEND if self._draft_is_moe else None
            ),
            draft_worker_cls=draft_worker_cls, # 透传自定义类
        )
    self._draft_worker = bundle.draft_worker
    # ... 后续 draft_model_runner 等字段赋值不变 ...

```

评论区精华

本次 PR 无 review 评论和讨论线程，PR body 中作者提到未运行 GPU 和端到端测试，因为默认路径未变。

- 暂无高价值评论线程

风险与影响

- 风险：风险极低：改动为纯参数注入，默认路径不变，不影响现有行为。但存在轻微风险：新增的 `draft_worker_cls` 参数未加类型校验，若调用方传入不兼容的类，可能导致后续属性访问失败；另外，`build_draft_tp_worker` 会在 `draft_model_build_scope()` 上下文中实例化自定义 worker，若自定义类有额外初始化逻辑可能受该 `scope` 影响。
- 影响：影响范围小：仅影响 DSpark 的初始化路径，默认用户无感知；对需要自定义 draft worker 的 out-of-tree 集成方提供了扩展点，增强扩展性。CRITICAL 风险低，但缺少测试覆盖是主要隐患。
- 风险标记：缺少测试覆盖

关联脉络

- 暂无明显关联 PR